

**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU**  
**ELEKTROTEHNIČKI FAKULTET**

**Sveučilišni studij**

**USPOREDBA METODA ZA DOHVAĆANJE ZNAČAJKI**  
**PRI KLASIFIKACIJI TEKSTURA**

**Završni rad**

**Josip Baketarić**

**Osijek, 2015.**

# SADRŽAJ

1.	UVOD .....	1
1.1.	Zadatak rada .....	1
2.	KLASIFIKACIJA UZORAKA.....	2
2.1.	Opis problema.....	2
2.2.	Metode dohvaćanja značajki .....	3
2.2.1.	Histogram.....	3
2.2.2.	Lokalni binarni uzorci .....	3
2.2.3.	Valići .....	5
2.2.4.	Matrice prostorne ovisnosti sivih tonova .....	6
2.3.	Klasifikatori .....	8
2.3.1.	Naivni Bayesov klasifikator .....	8
2.3.2.	Metoda najbližih susjeda.....	9
2.3.3.	Metoda vektora podrške .....	10
2.3.4.	Umjetna neuronska mreža.....	11
2.3.5.	Stabla odluke .....	12
2.4.	Analiza pereformansi klasifikatora.....	12
2.4.1.	Metoda izdvajanja .....	13
2.4.2.	Unakrsna provjera .....	14
3.	USPOREDBA METODA DOHVAĆANJA ZNAČAJKI .....	15
3.1.	Opis eksperimenta .....	15
3.2.	Opis programskog rješenja .....	15
3.3.	Alat za rudarenje podacima Weka.....	21
3.4.	Analiza rezultata .....	24
4.	ZAKLJUČAK .....	29
5.	LITERATURA.....	30
6.	SAŽETAK.....	31
7.	ŽIVOTOPIS .....	32

## 6. SAŽETAK

U radu su analizirane tri različite metode za dohvaćanje značajki pri klasifikaciji tekstura. Korištene metode su histogram, LBP te Haarova valić metoda. U teorijskom dijelu objašnjene su metode za dohvaćanje značajki, neki klasifikatori, metode za ocjenjivanje klasifikatora i načini implementacije metoda. Praktični dio sastoji se od implementacije navedenih metoda u programskom jeziku C# te od analize rezultata u alatu za rudarenje podacima Weka. Ova tema postaje sve više popularna u svijetu jer je doba digitalizacije i računala te se sve pokušava svesti na to da računalo što više posla obavi umjesto ljudi kako bi se uštedjelo što više vremena, a time i novca. Prema dobivenim rezultatima najbolja metoda, na primjenjenim teksturama, je histogram.

**Ključne riječi:** Haarov valić, histogram, LBP, texture, Weka.

## ABSTRACT

Comparing feature extraction methods for texture classification

This paper analyses three different methods for extraction features during texture classification. The utilized methods are: histogram, LBP and the Haar wavelet method. The theoretical part of the paper elaborates on the methods for extraction features, some of the classifiers, methods for evaluating classifiers as well as on the ways of implementing the methods. The practical part of the paper is comprised of two sections: the implementation of the previously mentioned methods in a programming language C#, and the analysis of the results in a data mining tool Weka. This topic is constantly gaining popularity nowadays due to the digital era in which the computer is doing most of the work, so people can save time, as well as money.

**Key words:** Haar wavelet, histogram, LBP, textures, Weka.